

# TeleTrust-Konferenz 2019

Bundesverband IT-Sicherheit e.V. (TeleTrust)

Berlin, 28.11.2019

## IT-Sicherheit & Maschinelles Lernen

Dr. Sven Herpig, Stiftung Neue Verantwortung

# Maschinelles Lernen in Safety-kritischen Bereichen

Gesichtserkennung in Überwachungskameras  
Krisenvorhersage/ -prevention  
Judikative Prozesse (inkl. Übersetzungen)  
Prozessoptimierung in kritischen Infrastrukturen

Nachrichtendienstliche Aufklärung, Datensammlung und Auswertung

Propaganda/ Desinformationskampagnen  
Militärische Entscheidungsfindung und Logistik  
Simulationen und Training

Steuerung von unbemannten militärischen Systemen (Fahrzeuge, Drohnen usw.)  
Semi-autonome lethale Waffensysteme und Gegenmaßnahmen

Offensive und defensive Cyberoperationen  
Gegenmaßnahmen zu ML-Systemen

u. v. m.

# Maschinelles Lernen und IT-Sicherheit

Maschinelles  
Lernen für  
**mehr** IT-  
Sicherheit

Maschinelles  
Lernen für  
**weniger** IT-  
Sicherheit

IT-Sicherheit  
**von**  
Maschinellern  
Lernen

October 2019 · Dr. Sven Herpig

# Securing Artificial Intelligence

Part 1: The attack surface of machine learning and its implications

 Stiftung  
Neue  
Verantwortung

ThinkTank für die Gesellschaft im technologischen Wandel

# “Wenn Du nicht mehr weiter weißt, gründe einen Arbeitskreis!”

*Transatlantic Cyber Forum [TCF] Working Group on “Information Security of Machine Learning” (gegründet 01/2019)*

Charles-Pierre Astolfi, French Digital Council

Daniel Castro, Center for Data Innovation

Thomas “halvarflake” Dullien, [optimyze.cloud](https://www.optimyze.cloud)

Joseph L. Hall, Center for Democracy & Technology

Maximilian Heinemeyer, Darktrace

Wyatt Hoffman, Carnegie Endowment for International Peace

Sven Jacob, BSI

Lydia Kostopoulos, ESMT Berlin

Johannes Otterbach, OpenAI

Thomas Reinhold, [cyber-peace.org](https://www.cyber-peace.org)

Matthias Schulze, SWP

Sven Weizenegger, [SUZA.io](https://www.suza.io)

Cathleen Berger, Mozilla

Betsy Cooper, Aspen Tech Policy Hub

Kenneth Geers, Atlantic Council [Fellow]

Mary Hanley, The University of Chicago

Ariel Herbert-Voss, Harvard University

Michael Hsieh, Transformative Cyber Innovation Lab

Frederike Kaltheuner, Privacy International

Igor Mikolic-Torreira, Georgetown University

Jörg Pohle, Humboldt Institute for Internet and Society

Kate Saslow, Stiftung Neue Verantwortung

Caroline Sinderson, Harvard Kennedy School

28.11.2019, TeleTrust-Konferenz 2019

# Angriffsoberfläche von Maschinellem Lernen

 Stiftung  
Neue  
Verantwortung

Think Tank für die Gesellschaft im technologischen Wandel

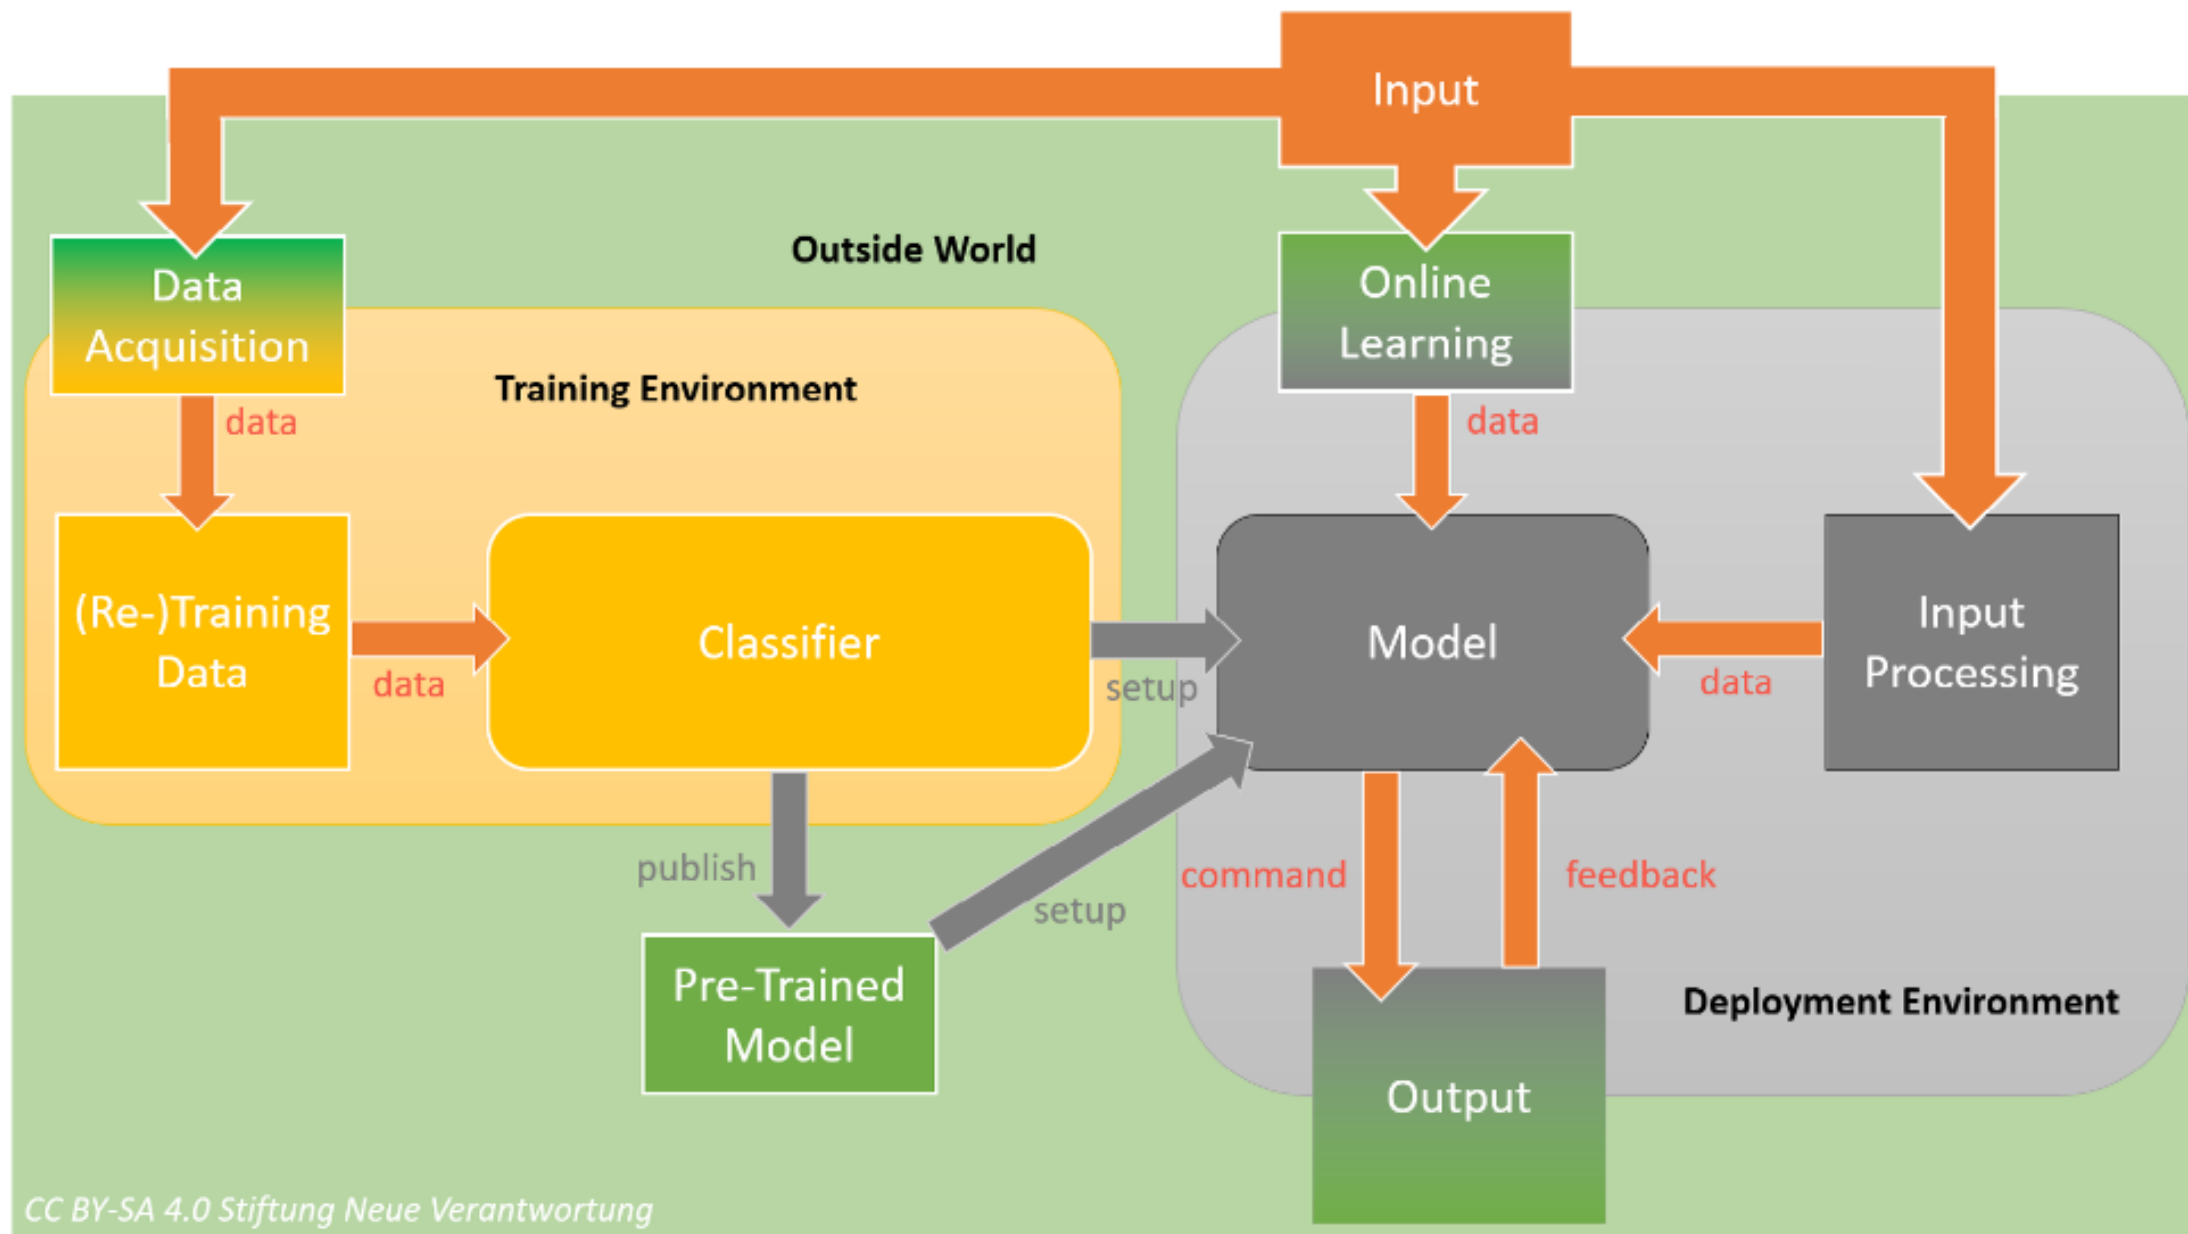


Figure 2: Attack surface of machine learning

## Beispiel: ML-spezifische Supply Chain

1. Trainingsdaten per se (z. B. Verschlusssachen)
2. Datenbeschaffung (3<sup>rd</sup> Party oder 4<sup>th</sup> Party)
3. Datenverarbeitung (z. B. Outsourcing vom Labeling)
4. Trainieren des Models (z. B. unter Nutzung von Cloud-Anbietern)
5. Vortrainierte Modelle (u. a. von GitHub)
6. Live-Trainingsdaten (u. a. bei Online Learning/ Federated Learning)



## Erkenntnisse – nicht ganz neu, aber teilweise anders

1. Die Angriffsfläche ist weitläufig und teilweise schwer bis gar nicht zu kontrollieren, was auch bei der Detektion und Attribution von Angriffen zu zusätzlichen Herausforderungen führt
2. Durch Angriffe auf ML-Systeme können verschiedenste Ziele erreicht werden, die möglicherweise -- auch wegen der Geschwindigkeit, Automatisierung und Skalierung -- zu Domino-Effekten führen können.
3. Das richtige “Threat Modeling” ist ein Kernstück um die IT-Sicherheit von ML-Systemen zu gewährleisten (u. a. ML-spezifische Supply Chain oder eingestufte Trainingsdaten)
4. Eine umfassende Betrachtung, sowohl vertikal (konventionelle IT-Sicherheitsherausforderungen) als auch horizontal (offensive und defensive Einsatzszenarien von ML), und eine klare Priorisierung der Schnittstelle von IT-Sicherheit und Maschinellen Lernen in der Nationalen KI-Strategie sind zwingend notwendig

“Even though it is difficult to predict whether information security will become a precondition for the successful development of machine learning going forward, securing machine learning, especially when it comes to [safety-critical deployment environments], is indispensable”

# **Securing Artificial Intelligence**

## **Part 2: Policy Recommendations To Better Secure Machine Learning**



# Quo Vadis – “Politik”

## Enquete-Kommission “Künstliche Intelligenz” des Deutschen Bundestags

- Bericht der Arbeitsgruppe “KI & Staat”

## Deutsches Institut für Normung (DIN), Deutsche Kommission Elektrotechnik (DKE) und Bundesministerium für Wirtschaft und Energie (BMWi)

- Auftaktveranstaltung zur Arbeitsgruppe “IT-Sicherheit bei KI-Systemen” (10/2019)

## European Telecommunications Standards Institute (ETSI)

- Industry Specification Group “Securing Artificial Intelligence” (09/2019)

## Plattform Lernende Systeme

- Bestandsaufnahme und Lösungsansätze “Künstliche Intelligenz und IT-Sicherheit” (04/2019)

## Stiftung Neue Verantwortung:

- Problemanalyse “Attack Surface of Machine Learning and Its Implications” (10/2019)
- Beitrag “IT-Sicherheit von Maschinellem Lernen” für die AG “KI & Staat” der Enquete-Kommission
- Agenda Setting auf deutscher und europäischer Ebene
- Teil 2 der “Securing Artificial Intelligence” Reihe, vermutlich in 10/2020

u. v. m.

As the day draws closer when the impact of human-made climate change will render the planet uninhabitable, it is perfectly understandable to be less worried about cybersecurity.

**Dr. Sven Herpig**

Leiter “Internationale Cybersicherheitspolitik”

sherpig@stiftung-nv.de

@z\_edian (Twitter)

Think Tank für die Gesellschaft im technologischen Wandel